

非破壊検査におけるトモシンセシス技術の応用

Shiina, Hiroki / 椎名, 大樹

(出版者 / Publisher)

法政大学大学院理工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学研究科編

(巻 / Volume)

64

(開始ページ / Start Page)

1

(終了ページ / End Page)

6

(発行年 / Year)

2023-03-24

(URL)

<https://doi.org/10.15002/00026399>

非破壊検査における トモシンセシス技術の応用

Application of Tomosynthesis Technology in Non-Destructive Inspection Imaging

椎名大樹

Hiroki Shiina

指導教員 尾川浩一

法政大学大学院理工学研究科応用情報工学専攻修士課程

In non-destructive inspection of substrates, a technique called X-ray tomosynthesis method has made it possible to inspect sliced layers. But inspection of precision machine substrate by a non-destructive inspection may miss small defective parts by the effect of pins for cooling process. The purpose of this study is to eliminate the effect of pins in substrate inspection and to improve image quality. The paper reviews the results of a rolling ball method, simple calculation method, band pass filter method, and deep image prior for removing pins. In addition, this paper also proposed that small defectives areas be made higher resolution by a super-resolution technique. Comparing the resultant images, the band-pass filtered reconstructed images showed the best results. In addition, super-resolution by machine learning was also found to be effective in improving image quality.

Key Words : *non-destructive inspection, machine learning, super-resolution*

1. はじめに

非破壊検査では物体の状態を変化させることなく、非接触で物体の内部を検査することができる。この検査方法は工業製品の検査や、建築物に対する検査などさまざまな用途に利用されている。非破壊検査における方式としては、超音波検査、X線検査、磁気検査、放電現象検査などがある。それぞれの検査は、音波や磁気、投影による画像化によって検査対象の欠陥を発見することができる。また、一見しただけでは判断することができない画像も画像処理を施すことによって細かい異常も発見することができるようになる。

この画像処理には機械学習が用いられている例もある。非破壊検査に関してはビルの材料の異なるタイルのひび検査[1]や、コンクリート内部の空隙検査[2]などに使用されている。ひび検査に関しては音が使用される機械学習、そして空隙検査の場合、X線投影による画像を使用したCNNがそれぞれ利用されている。また、医療分野における使用例としては、U-Netを用いたSPECT画像の画質改善やコーンビームCTによる画像のノイズ除去などに使用されている。

本研究で対象とする精密機械に用いる基板に対する検査には、はんだ部と基板接合界面での面積比較・形状比較検査、IGBT(パワーモジュール)放熱Pinフィン情報除去検査などがある。これらの検査により基板上面の細かな異

常である、フィルムを貼る際に生じてしまう気泡や、はんだ不良(接続に用いるためのはんだが正常に接着していない状態)、そしてブリッジ不良(隣接したはんだ同士が接触してつながってしまう状態)などを視認することで基板界面における検査をおこなっている。しかし、通常のX線投影では基板の裏側にあるチップなどが映り込んでしまい検査したい基板表面の画像がうまく映らない場合がある。FX-300tRX2/LL[3]ではX線ステレオ方式を用いることで裏面のチップをキャンセルできるようになり、特定のスライス面における検査が可能になった。

2. X線ステレオ方式

X線ステレオ方式は、医療画像診断において乳房の検査の画像再構成法であるトモシンセシスを応用している。

X線ステレオ方式は、物体に対してX線の入射角を変化させながら撮影する。CTのような物体に対して一周させるような通常の投影方法と違い、トモシンセシスは限定角度のみで投影を行うため、従来のX線CT方式と比較して検査時間の大幅な短縮、装置のサイズ、コストなど様々な点において優れた効果がある。撮影された投影画像は対象の全ての内部の情報を持っているが、このままだと本来検査したい部分のみの画像が得られないため shift-and-add法を用いて、基板のスライス断面の画像を再構成する。

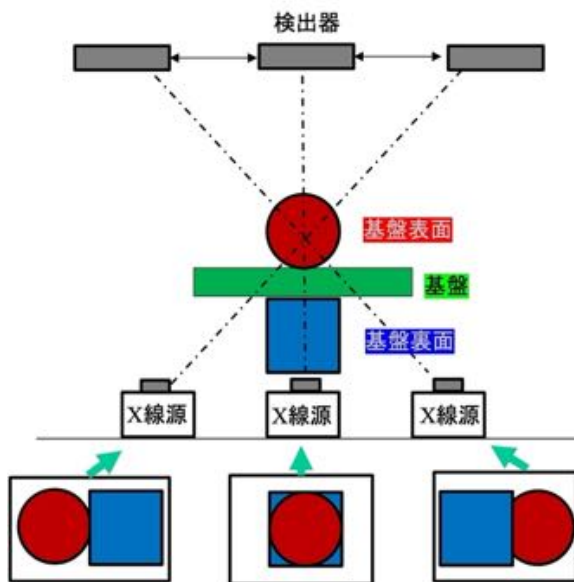


図1 X線ステレオ方式原理図

3. 研究目的

X線ステレオ方式によって基板スライス面の検査が可能になったが、この方式を使用して画像を再構成するとそのスライスに存在しないはずの裏面のピンの影が残ってしまう。それによって検査においてその異常を視認する際に影が邪魔になってしまい、検査の正確性が低下してしまう恐れがある。そこで、上記画像処理や機械学習使用例を参考にし、精密機械基板におけるはんだまくら不良や気泡の抽出を行うためのピンの除去手法の検討、および不良部分における超解像による画質改善手法を提案する。

元となる投影画像は、基板の検査において実機で使用される条件を用いた。以下に投影時のジオメトリと投影条件を示す。




図2 投影時のジオメトリ

Table1 投影条件

検査領域	38.5mm×6.0mm×48.7mm
検出器サイズ	114.9mm×145.4mm
X線源軌道	y軸中心の楕円軌道
軌道半径(x, z)	(31.6mm, 43.0mm)
投影数	40
ピクセルサイズ	74.8 μm
xz面と線源の距離	59.6mm
xz面と検出器の距離	54.3mm

検査領域内には基板が配置されている。検出器サイズは114.9mm×145.4mmであるが、ピクセルサイズが74.8 μmなのでピクセル数で表すと1536×1944pixelsとなる。

以下に実機により得られた投影画像を示す。




図3 実機で得られた基板投影画像
(a) 投影角度0度, (b) 投影角度90度

検査によって得られた正常投影画像と異常のある投影画像を用いて shift-and-add 法による画像再構成を行った結果を図4に示す。

20 スライス目には気泡の異常が現れている。42 スライス目にはチップ部分にはんだ不良が存在するがうまく視認できない。

4. シミュレーション内容

(1) CNNのためのデータセット作成

教師データとして、256×256[pixels]の基板投影画像を180枚用意した。これは元々の検出器のサイズである1536×1944[pixels]をそのプログラム内にて縮小することで作成した。また、モデルに合わせて画素値が[0:1]の範囲になるように正規化を行った。教師データは真の画像が存在しないため、基板に使用されている素材と同じの銅板を投影した画像を使用した。訓練画像と教師データで計540枚のデータを作成し、そのうち90%を訓練データ、10%を検証データとした。条件は、エポック数が200、バッチ数は64、損失関数はMean Squared Error (MSE)、最適化アルゴリズムはAdamを使用した。




図4 再構成画像(a)正常(20スライス目), (b)異常(20スライス目), (c)正常(42スライス目), (d)異常(42スライス目)

(2) ピンの除去法

a) Rolling Ball

基板投影画像に対して半径 100[pixels]の円を想定しピンの除去を行った。画像の上に円を転がすようにし、その円が通った箇所を補正後の画素値とした。これにより穴の空いたようなピンの部分を除去した。これを 40 投影分行い、それらを用いて shift-and-add 法によってスライス面の画像再構成を行った。

b) 単純な計算

単純な計算によるピンの除去手順について説明する。

- ① まずピンのみの画像に対して閾値処理をかけることでピン部分のマスク画像を作成する。今回の投影画像は明るい箇所が投影角度ごとに異なっているので、この時に作成したマスク画像にDilation(膨張)処理をかけることでピン部分を完全に覆うようにする。
- ② 投影画像に対して、半径100pixelの大きさの円を想定した Rolling Ball をかけ、ピンを埋めた画像を作成する。
- ③ ①で作成したマスク画像と②で作成した画像でAND処理をかける。これによりピン部分のみ画素値がある画像を作成する。
- ④ 元の投影画像と③で作成した画像でMAX処理をかける。

これによりピン部分の平滑化ができる。Rolling Ball は投影画像全体に平滑化をかけ全ての画素値を変化させるが、この方法による処理はピン部分のみの画素値を変化させ

ているため、より信頼性の高い画像が取得できる。上記手順を 40 投影分行い、それらを用いて shift-and-add 法によってスライス面の画像再構成を行った。

c) バンドパスフィルタ

今回検出したい異常ははんだ不良や気泡のような画像のコントラストが低い部分であるため、帯域通過フィルタであるバンドパスフィルタが有効でありこれを試みた。

まず異常のある基板投影画像を用いて shift-and-add 法によって画像再構成を行った。この再構成画像にバンドパスフィルタをかけていく。再構成画像をフーリエ変換により周波数成分に変換し、カットオフ周波数を $f_0 = 2Hz$, $f_1 = 50Hz$ として設定しフィルタリングを行った。その後逆フーリエ変換により元の画像に戻した。

d) Deep Image Prior

Deep Image Prior(DIP)[4]は正解ラベルとなる画像を使わずにデノイズングできる手法である。ノイズのようなランダム生成された画像と通常の画像は、自然の画像の方が誤差を小さくする速度、つまり学習速度が速く綺麗な画像に速く収束できる。この学習速度の差を利用して、ノイズを学習する前に学習を止めることでノイズを含まない綺麗な画像が出力することができるという内容である。

異常のある基板投影画像を中心部分 1024×1024pixels に切り取る。切り取った画像と b) で作成したマスク画像を用いてピン部分を覆う形で入力画像とした。画像の構築には CNN の構造が必要であるため U-Net[5]を参考にした。この処理を 40 投影分行い出力された投影画像を shift-and-add 法で再構成した。

(3) 超解像

超解像は、解像度の低い観測された画像では正しく表現できない高周波成分の情報を復元する技術である。細かいはんだ不良を検知するために、異常点の解像度を上げることを試みた。学習型の超解像処理は大量の画像から高解像度化に必要な特徴量を学習し、それを用いて低解像度画像から高解像度画像を生成する技術である。今回は GAN ベースの手法である SwinIR[6]と Real-ESRGAN[7]、そして拡散ベースである Super-Resolution via Iterative Refinement(SR3)を用いて超解像を行った。今回モデルは DIV2K[8]や OutdoorSceneTraining[9]による学習済みモデルを使用した。

異常のある投影画像を入力画像として学習済みネットワークにて超解像を行った。入力画像ははんだ不良のある 42 スライス目画像を使用し、1536×1944pixels の画像を 6144×7776pixels にして解像度を高めた。異常部分を拡大し比較を行った。

5. 結果と考察

(1) ピンの除去

Rolling Ball によるピンの除去を行った投影画像による再構成画像、単純な計算によるピンの除去を行った投影画像による再構成画像、バンドパスフィルタにより異常を検

出しやすくした再構成画像,Deep Image Prior によってピンの除去を行った再構成画像を以下に示す.




図5 補正法の比較(20 スライス目) (a)Rolling Ball による補正再構成画像, (b)単純な計算による補正再構成画像, (c)バンドパスフィルタをかけた再構成画像, (d)Deep Image Prior による補正再構成画像

まず,20 スライス目は気泡の異常が多く出ているスライスである.Rolling Ball による補正は,基板の構造が見えないほど再構成画像はぼやけてしまった.次に単純な計算による補正画像も基板構造が失われてしまった.最後にバンドパスフィルタによる補正と Deep Image Prior による補正はその基板構造,そして気泡部分もしっかりと視認できるほどの画像が出力された.

次に 42 スライス目の再構成画像を示す.42 スライス目はほとんど不良が現れているスライスである.




図6 補正法の比較(42 スライス目) (a)Rolling Ball による補間再構成画像, (b)単純な計算による補間再構成画像, (c)バンドパスフィルタをかけた再構成画像, (d)Deep Image Prior による補間再構成画像

バンドパスフィルタによる補正と Deep Image Prior による補正は基板構造をとどめていた.チップ部分に関しては拡大しないと確認できないため,以下に不良のあるチップ部分の拡大画像と示す.また不良部分と背景であるチップ部分のコントラスト比を評価値として使用する.コントラスト比は対象画素値を a,背景画素値を b としたとき,

$$\frac{b-a}{b} \times 100(\%) \quad (1)$$

で表せられる.




図7 右上チップの,補正なし再構成画像とそのプロファイル(上),バンドパスフィルタによる補正画像とそのプロファイル(中央),Deep Image Prior による補正画像とそのプロファイル(下)

Table 2 結果画像コントラスト比

	不良部分画素値	背景画素値	コントラスト比
補正なし画像	132.343	164.651	19.622
バンドパスフィルタ	90.630	132.773	31.740
Deep Image Prior	106.765	124.314	14.117

大きい不良部分に関しては両方とも再構成できているが,さらに細かい部分についての再構成は Deep Image Prior による再構成よりバンドパスフィルタによる鮮明化の方がはっきりと再構成できていることが確認できた.また,バンドパスフィルタによる補正は補正なし画像よりコントラスト比が高く,視認性が向上していることが確認できた.

続いて左上のチップを拡大したものとプロファイルを以下に示す。




図8 左上チップの、補正なし再構成画像とそのプロファイル(上)、Deep Image Priorによる補正画像とそのプロファイル(下)

Deep Image Priorによる補正画像では本来のチップには見られない線状の構造が確認できた。これはこの補正方法がマスク部分の補間をする際に、その周辺画素から情報を予測するため、このチップ上部の基板構造が延長される形で修復されてしまったと考えられる。

(2) 超解像による高解像度画像結果

それぞれの超解像手法による結果画像を以下に示す。




図9 (a)補正なし再構成チップ画像、(b)SR3による超解像チップ画像、(c)SwinIRによる超解像チップ画像、(d)Real-ESRGANによる超解像チップ画像

補正なし再構成画像のチップ部分のサイズは 64×64 pixelsであったが超解像後はいずれもそのサイズは4倍に拡大した。SR3による超解像は高周波成分である梨状テクスチャがあらわれた。チップの構造自体はSwinIRによるものよりReal-ESRGANによる画像の方がより詳細な画像が出力されたことが確認できた。以下に左中央部の

不良部分を通った補正なし画像のプロファイルとReal-ESRGANによる画像のプロファイルを示す。




図10 補正なしチップ画像のプロファイル y=96(上)、Real-ESRGANによる補正チップ画像のプロファイル y=335(下)

同じ領域のコントラスト比はそれぞれ 19.662%、22.563%となり高くなり、また高周波成分を復元したことで不良部分の境目のエッジが立ち視認性が向上した。

6. まとめ

本研究では、精密機械基板検査において画像処理や機械学習を用いてその有用性を実機によって得られたデータをもとに比較し検証した。結果としてバンドパスフィルタや超解像による高解像度化によって異常部分を鮮明化させ、視覚的に検知しやすくなった。

謝辞：本研究にあたり、全般にわたりご指導をいただきました尾川浩一教授、また、随所でご教示いただいた尾川研究室の皆様方に感謝いたします。

参考文献

- 1) Fukumura, T., Aratame, H., Ito, A., Koike, M., Hibino, K., & Kawamura, Y. (2020). An Efficient Learning Method for Sound Classification using Transfer Learning for Hammering Test. *2020 IEEE Sensors*, 1-4.
- 2) L. Ali, N. K. Valappil, D. N. A. Kareem, M. J. John and H. Al Jassmi. (2019). Pavement Crack Detection and Localization using Convolutional Neural Networks (CNNs). Sharjah, United Arab Emirates, 2019, pp. 217-221.
- 3) "「X線ステレオ方式」3次元X線自動検査装置 FX-300tRX2", "<http://i-bit.co.jp/products/FX-300tRX2>,"

300tRX2.html"2023年2月8日アクセス。

- 4) Ulyanov, D., Vedaldi, A., and Lempitsky, V.S. (2017). Deep Image Prior. *International Journal of Computer Vision*, 128, 1867-1888.
- 5) Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *ArXiv, abs/1505.04597*.
- 6) Liang, J., Cao, J., Sun, G., Zhang, K., Gool, L.V., & Timofte, R. (2021). SwinIR: Image Restoration Using Swin Transformer. *2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*, 1833-1844.
- 7) Wang, X., Xie, L., Dong, C., & Shan, Y. (2021). Real-ESRGAN: Training Real-World Blind Super-Resolution with Pure Synthetic Data. *2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*, 1905-1914.
- 8) Agustsson, E., & Timofte, R. (2017). NTIRE 2017 Challenge on Single Image Super-Resolution: Dataset and Study. *2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 1122-1131.
- 9) Wang, X., Yu, K., Dong, C., & Loy, C.C. (2018). Recovering Realistic Texture in Image Super-Resolution by Deep Spatial Feature Transform. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 606-615.